information s	search and detection m thod for information network	
Patent Number: Publication date: Inventor(s): Applicant(s):: Requested Patent: Application Number; Priority Number(s): IPC Classification: EC Classification:	DE19725264  1998-10-15  LERENC VEDRAN (DE); SANDVOSS JOCHEN DR (DE)  IBM (US)  DE19725264  DE19971025264 19970613  DE19971025264 19970613; DE19971014741 19970409  H04L12/16; H04M3/42; G06F13/00	
Equivalents:	□ <u>JP1032629</u> 0	
Abstract		
The method involves searching and detecting information in an information network according to requirements of a user. The information is transmitted to the user. The information network has at least one network node providing information. First the requirement of the user is transmitted to an agent which carries out the requirement in the information network decoupled from the user. Preferably the required information can not be previously localised in the network. The user can access the information network by a network supplier.		
·	Data supplied from the esp@cenet database - I2	





#### 19 BUNDESREPUBLIK DEUTSCHLAND

# ® Offenl gungsschrift <sup>®</sup> DE 197 25 264 A 1

⑤ Int. Cl.6: H 04 L 12/16



**PATENTAMT** 

- ② Aktenzeichen: Anmeldetag:
- 197 25 264.8 13. 5.97
- 49 Offenlegungstag:
- 15. 10. 98

H 04 M 3/42 G 06 F 13/00

Innere Priorität: 197 14 741.0

09. 04. 97

7 Anmelder:

International Business Machines Corp., Armonk, N.Y., US

Wertreter:

Teufel, F., Dipl.-Phys., Pat.-Anw., 70569 Stuttgart

Erfinder:

Lerenc, Vedran, 68753 Waghäusel, DE; Sandvoss, Jochen, Dr., 68159 Mannheim, DE

66 Entgegenhaltungen:

N.N.: Dienstboten-Software, in: Funkschau, 1996, Heft 8, S. 54-56;

## Die folgenden Angeben sind den vom Anmelder singereichten Unterlegen entnommen

Prüfungsantrag gem. § 44 PatG ist gestellt

- (A) Verfahren und Einrichtung zur Optimierung der Auslastung von Leitungeressourcen bei Informationsenforderungen in einem Informationsnetz
- Beschrieben wird ein neuartiger Dienst zur Verarbeitung von Benutzeranforderungen in Informationsnetzen wie betriebsinternen Intranets oder dem World Wide Web, der bevorzugt in Informationsnetzen mit beschränkten Leitungsressourcen und in denen die gesuchten informationen im voraus nicht geneuer lokalisierber sind, einsetzbar lat. Dieser Dienst lat innerhalb des Leltungsnetzes angeordnet und ermöglicht eine Hintergrund- bzw. Stapelverarbeitung der Anforderungen. Entsprechend einer ersten Optimierungsstufe übernimmt der Dienst mit der Übermittlung einer Anforderung, unabhängig vom Benutzer, die Ausführung des Suchauftrags. Durch die im Hintergrund ablaufende Verarbeitung wird Insbesondere die Möglichkeit gescheffen, die Startzeit bzw. den Zeitab-lauf der Bearbeitung eines Benutzerauftrages so zu steuern, daß die Leitungskosten insgesamt minimiert werden. Entaprechend einer zweiten Optimierungsstufe wird eine Entkapplung der Abwicklung von Anforderungen über das Informationsnetz und der Bearbeitung von Aufträgen beim Dienst selbst vorgeschlagen.

1

#### Beschreihung

Die Erfindung betrifft ein Verfahren und eine Einrichtung zur Verarbeitung von Anforderungen in Client/Server-basierten Informationsnetzwerken, bei denen ein Server im Auftrag eines Client bestimmte Aufgaben in einem betriebsinternen Intranet oder dem Internet durchführt, wobei die Anforderungen über meist stark frequentierte Leitungsverbindungen vom Client zum Server übertragen werden. Die Erfindung ist bevorzugt dort einsetzbar, wo Informationen in einem Informationsnetz abgerufen werden, insbesondere in einem Netz, in dem die Informationen im voraus nicht genauer lokalisierbar sind.

Das World Wide Web (WWW) als derzeit populärster Dienst des Internet hat in jüngster Vergangenheit einen be- 15 achtlichen Aufschwung im Bereich von Informationen aller Art erfahren. Internetbenutzer können durch das Netz "Surfen" und sie interessierende Informationen in recht einfacher Weise zusammensuchen. Jedoch stellt sich dieses Surfen im allgemeinen als sehr zeitaufwendig dar, und auch im Zeital- 20 ter der Hochgeschwindigkeitsilbertragungseinrichtungen wie "ISDN" sind die erforderlichen Leitungsverbindungen nicht schneller als das langsumste Glied in der Kette der Verbindungen zwischen dem Benutzer und dem jeweiligen Ursprungsort der gesuchten Informationen. Eine der Ursa- 25 chen dafür ist die Tassache, daß die eigentlichen Informationswege beim sogenannen "TCP/IP"-Übertragungsprotokoll (Transmission Control Protocol/Internet Protocol) im allgemeinen nicht vorherschbar sind und damit schlechte Teilverbindungen einer gesamten Leitungsverbindung den 30 Datendurchsatz reduzieren.

Aus diesen Gründen fallen beim Endbenutzer des Internets zum einen erhebliche Kosten für die Unterhaltung der erforderlichen Telefonverbindung zum Netzanbieter an. Anderenseits erfordert das Surfen große Zeitaufwendungen, bis 35 die gesuchten Informationen letztlich auf dem Bildschirm der Benutzers erscheinen.

Darüber hinaus wird das Internet zunehmend auch im geschäftlichen Umfeld als Kommunikationsmedium genutzt. Nach einem Bericht ("WWW-User-Report"), April/Mai 40 1996, auf den beispielsweise in Internet Business, Verlag Neue Mediengesellschaft, Ulm, Herausgeber W. Dreyer und H. Summa, verwiesen wird, stellen derzeit mehr als die Hälfte der Internet-Benutzer Geschäftskunden dar. In diesem Bereich sind allerdings die gewohnten hohen Antwort- 45 zeiten bei einer Nachsuchung von Informationen nicht tragbar. Es wird an dieser Stelle hervorgehoben, daß schnellere Leitungsverbindungen zwischen dem Internetanbieter und dem Internet in der Regel keine höberen Datendurchsätze ermöglichen, da. wie oben bereits ausgeführt, die Neuoüber- 50 tragungsraten im wesentlichen durch Engpässe in der gesamten Übertragungskette bestimmt sind. In dem besonderen Fall, daß der Engpaß bei dem Netzanbieter selbst begründet ist, können die Durchsarzraten im allgemeinen durch verbesserte Leitungsverbindungen bedeutend erhöht 55 werden, was allerdings weitere Kosten hei dem Netzanbieter und damit letzilich beim Endbenutzer verutsacht.

Ein vorrangiges Ziel auf Seiten des Netzanbleters ist jedenfalls eine optimale Auslastung der Internetzugriffe, und somit besteht beim Netzanbieter ein erhebliches Interesse an 60 Technologien zur Minimierung oder Vermeidung von Datenübertragungsspitzen und zur möglichst homogenen Verteilung der Netzanslastung im Tagesverlauf. Im weiteren Interesse des Netzanbieters liegt daher ein möglichst gleichmäßig über die Zeit verlaufender Datenverkehr, wobei Netzwerkzugriffe kontinuierlich bei optimalen Übertragungsraten erfolgen.

Zusätzlich besitzen die Benutzer des Internets für ge-

wöhnlich nur ein geringes Know how über den im Hintergrund ablaufenden Datenverkehr im Netz. Sie werden lediglich mit relativ niedrigen Durchsatzraten konfrontiert, ohne
dabei deren Finterpründe und Ursachen genauer zu kennen.
Neben den vorgenannten, seitens der Netzanbieter bereitgestellten Diensten besteht somit auch ein Bedarf an einem zusätzlichen Dienst, der sowohl beim Netzanbieter als auch
beim Endbenutzer zu einer Steigerung des Datendurchsatzes
beiträgt. Dies setzt allerdings bei einem solchen Dienst auch
besondere Kenntmisse über Netzwerktopologien und Datenübertragungsverkehr und deren Umsetzung beim Datenver-

2

Im Bereich von benutzerspezifizierten Anforderungen in Informatiousnetzen existieren zudem bereits eine Reihe von Ansätzen zur Bewältigung der enormen Informationsflut. Diesen liegt die Erkenntnis zugrunde, daß das Surfen im Internet ein recht zeitintensives Unterfangen darstellt und darüber hinaus die empfangenen Informationen nicht genereil von Interesse für den jeweiligen Benutzer sind.

Einen ersten Ansatz stellen sogenannte "intelligente Agenten" dar, welche die "online" verfügbare Information nach denjenigen Informationen durchforsten, die für den Benutzer von besonderem Interesse sind. Ein entsprechendes Agentenprogramm wird beispielsweise in einem Artikel von D. Jeapes mit dem Titel "Neural Intelligent Agents" beschrieben, der in Online & CD ROM Review, Vol. 20, Nr. 5, Seiten 260–262, vorveröffentlicht ist. Darin beschrieben ist ein autonomes Programm, das auf neuronalen Netzen basiert. Bei diesem System teilt der Benutzer dem Agenten vor dem Beginn einer neuen Nachsuchung Informationen, beispielsweise über das gewünschte Fachgebiet, mit.

Ein äholicher der vorliegenden Gattung entsprechender Ausstz ist in einem Artikel von S. W. Loke et al. mit dem Titel "CiFi: An Intelligent Agent for Citation Finding on the World Wide Web", Springer Verlag Berlin, 1996, Konferenzeuszug zu PRICAI '96: Topics in Artificial Intelligence 4th Pacific Rim International Conference on Artificial Intelligence, beschrieben. Hierin wird ein regelbasierter Agent für das World Wide Web vorgeschlagen, der dem Benutzer beim Auffinden von Informationen zur Seite steht. Dieser Agent sucht und findet völlig autonom Webseiten, wobei er ein Spektrum an Suchstrategien anwendet. Ein heuristisches Suchverfahren steht hierbei im Vordergrund, bei dem die Nachsuchung zunächst in der im World Wide Web bekannten LYCOS-Suchmachine startet.

Ein weiteres agentenbasiertes Vorfahren im Bereich von Datenbankzugriffen bei Datenbanken unterschiedlichen Typs ist aus den vorveröffentlichten europäischen Patentanmeldungen EP 0 747 841, EP 0 747 843 und EP 0 747 844 bekannt. Der darin beschriebene intelligente Agent nimmt eine Vermittlerrolle zwischen einem Client und einem Server ein und veranlaßt auf Anforderungen des Client hin den Scrver dazu, die mit den Anforderungen verbundenen Aufträge völlig autonom abzuwickeln. Das besondere Augenmerk ist allerdings darauf gerichtet, die erforderlichen Routinearbeiten seitens des Benutzers möglichst zu minimieren bzw. Interventionen durch den Benutzer auszuschließen oder zumindest in großem Maße zu reduzieren. Die dan vorgeschlagene Lösung sieht einen Kontrollprogramm-Agenten vor, der zwischen einem Neizwerk und einem an das Notzwerk angegliederten Server angeordnet ist. Die beispielsweise von einem Web-Server verarbeiteten Benutzeranforderungen werden zunüchst an den Kontrollprogramm-Agenien weitergegeben, der wiederum die Bearbeitung der Anforderung in dem Netzwerk mittels Subagenten vornimmt Der Kontrollprogramm-Agent wiederum liefert nach Durchführung der entsprechenden Aufgaben die vollständigen Ergebnisse in Form eines Berichtes zurück an den

3

Client, und zwar in einer Darstellungsform und an eine Adrease gerichtet, die in der ursprünglichen Anforderung festgelegt wurden. Durch diese Vorgehensweise ist gewährleistet, daß der Benutzer nur einen Auftrag abgeben muß, wobei auch bier die eigentliche Arbeit von Agenten im Hutergrund übernommen wird.

Die genannten Lösungen führen zwar bereits eine Reihe von Erleichterungen für den Benutzer bei der Nachsuchung von Informationen in lokalen und/oder verteilten Informationsnetzen ein, sie haben allerdings noch den Nachteil, daß to die von einem Benutzer abgesetzten Anforderungen ohne Berücksichtigung des Zeitfaktors bearbeitet werden, und somit zeitabhängige Betriebskosten, z. B. anfallende Gebtühren bei den übertragenden Leitungsnetzen, keine Berücksichtigung finden.

Darüber hinaus haben diese Lösungen den weiteren Nachteil, daß den unterschiedlichen Übertragungskapazitäten der Leitungsverbindungen zwischen dem Endbenutzer und dem Informationsnetz nicht Rechnung getragen wird. Zwischen dem Endbenutzer und dem Netzanbieter liegen 20 meist Leitungsverbindungen extrem unterschiedlicher Übertragungsbandbreite, z. B. ISDN- oder Modern-Verbindungen zu den üblichen Schaltnetzen. So fallen für die Unterhaltung der Leitungsverbindungen zwischen dem Netzanbieter und einem im Informationsnetz angesiedelten Scrver in der Regel relativ geringe oder gar keine Kosten an, wohingegen der Verbindungsaufbau zwischen dem Endbonutzer und dem Netzanbieter sich in der Regel relativ kostenintensiy darstellt.

Der vorliegenden Erfindung liegt daher die Aufgabe zu- 30 grunde, ein Verfahren und eine Einrichtung der vorbeschriebenen Gattung bereitzustellen, die die vorgenannten Nachteile vermeiden und insbesondere eine Berücksichtigung der vorgenannten Zeit- und Kostenproblematik ermöglichen. Darüber hinaus soll mit der Erfindung zum einen eine 35 Grundlage dafür geschaffen werden, Zugangsnetze zu dem Informationsnetz hinsichtlich einer Lastverteilung optimieren zu können. Zum anderen soll mit Hilfe der Erfindung eine möglichet kontinuierliche Auslastung der Internet-Anbindung zwischen einem Netzunbieter, einem Intranet oder 40 einem Endhenutzer einerseits, und dem Internet andererseits, erreicht werden. Darüber hinaus wird auch eine möglichst optimale Ressourcenauslastung zwischen den bei der Bearbeitung von Benutzeranforderungen ablaufenden Prozessen und den für die Übertragung der Aufträge an das In- 45 temet erforderlichen Kommunikationsmitteln anvisiert.

Diese Aufgabe wird gelöst durch die Merkmale der unabhängigen Verfahrens- und Einrichtungsansprüche. Weitere bevorzugte und vorteilhafte Ausgestaltungen sind Gegenstand der jeweiligen Unteransprüche.

Im Rahmen einer ersten Optimierungsstufe gemäß der Erfindung wird ein kommerzieller Dienst bereitgestellt, der innerhalb des Leitungsnetzes angeordnet ist und der eine Hintergrundverarbeitung der genannten Benutzeranforderungen, insbesondere in Form einer Stapelverarbeitung, in dem ss Netz ermöglicht. Mit der Übermittlung einer Anforderung an den Dienst übernimmt dieser – unabhängig (entkoppelt) vom Benutzer – die Ausführung des Auftrags. Durch die im Hintergrund ablaufende Verarbeitung wird insbesondere die Möglichkeit geschaffen, die Starzeit bzw. den Zeitablauf 60 der Bearbeitung eines Benutzerauftrages so zu steuern, daß die Leitungskosten insgesamt minimiert werden.

Entsprechend einer zweiten Optimierungsstufe sieht die Erfindung vor, daß zur Erreichung einer möglichst komtinuierlichen Auslastung einer Interner-Anbindung ohne Überlast Situationen nicht mehr Anforderungen an das Internet abgegeben werden, als durch die naturgemäß begrenzte Bandbreite bearbeitet werden können, Daher werden Infor-

mationen (z. B. Dokumente), die den seitens des Anwenders spezifizierten Bedingungen genügen, nicht sofort angefordert, sondern einer Liste mit Zieladressen, z. B. Dokumentenadressen (URLs) hinzugefügt. Diese Liste oder Pool von Adressen wird für das Generieren bzw. Außetzen neuer Erfassungs- und Analyseprozesse genutzt, wenn ausreichend freie Bandbreite für die Bearbeitung verfügbar ist.

Im einzelnen werden die Verarbeitung der Benutzeranforderungen, z. B. die Analyse von bereits vorliegenden Informationen (Suche nach weiteren enthaltenen Referenzen) und das Anfordem von weiteren Informationen aus dem Internet, basierend auf bereits vorliegenden Ergebnissen der Analyse, unabhängig (entkoppelt) voneinander ausgeführt. Hierzu werden die Zwischenergebnisse, z. B. aufgefundene Referenzen (URLs), in einem Pool (Puffer) zwischengespeichert. Durch diese Maßnahmen wird insbesondere ermöglicht, daß eine Verarbeitung von Benutzeranforderungen (Analyseprozesse) auch bei etwa nicht vorhandenen freien Übertragungskapazitäten (Bandbreiten) fortgesetzt werden kann. Entsprechend können etwa vorliegende freie Übertragungskapazitäten optimal genutzt werden, indem im Puffer bereits zwischengespeicherte Auftragsadressen sofort für die weitere Auftragsprozessierung genutzt werden können. Durch die genannte Entkopplung wird somit eine kontinuierliche Auslastung der Internet-Anbindung ermöglicht.

Der erfindungsgemäße Dienst richtet sich besonders an die Bedürfnisse von Netzanbietern und ihren Kunden (Endbenutzer), sowie an Intranet-Administratoren. Mit Hilfe dieses Dienstes werden zudem sowohl auf der Anbieter- als auch auf der Anwender-(Benutzer-)Seite erhebliche Kosten eingespart. Dies wird - anstelle der bislang erforderlichen Online-Nachsuchungen - insbesondere durch eine im Hintergrund (offline) durchgeführte Bearbeitung der Benutzeranforderungen ermöglicht. Eine Hintergrundbearbeitung von Aufträgen ermöglicht dabei insbesondere die Anwendung von optimierten Zeitplänen für die Übertragung von Informationen sowohl innerhalb des Informationsnetzes als auch außerhalb des Netzes zwischen z. B. einem Netzanbieter und dem Endbenutzer. Aufgrund der dadurch ermöglichten optimalen Durchsatzraten an Netzwerkverbindungsstellen werden dabei erhebliche Kosten eingespart. Die vom Kunden gewünschten Informationen werden durch den erfindungsgemäßen Dienst in Zeiten geringer Netzwerkauslastung in dem Informationsnetz aufgesplirt und gesammelt, und erst nach Abschluß der Recherchen an den Endbenutzer überminelt

Die Übermittlung der gesammelten Informationen kann dabei in einem weiteren Ausführungsbeispiel der Erfindung erst auf Antrag des Benutzers erfolgen, wobei die Informationen zwischenzeitlich bei dem vorgeschlagenen Dienst selbst zwischengespeichert werden.

Bei ausreichender Sichening der Kommunikarion können die Informationen allerdings auch direkt zum Endbenutzer transportiert werden, z.B. in Form einer FTP-Upload.

Neben einfachen Aufträgen können auch Daneraufträge angenommen werden, die erwa werktags aktuelle Börsenkurse von Servern abrufen und dem Auftraggeber (Endbenutzer) als Informationspaket zur Verfügung stellen.

Ein weiterer Vorteil der Hintergrundverarbeitung ist die Entlastung des Bndbenutzers bei den Benutzereingaben, die gegenwärtig bet z. B. "Web-Browsern" noch interaktiv erfolgen mitssen. Diese Interaktivität wird bei der Erfindung ersetzt durch einen einmaligen Auftrag, der unter andexem die Suchbegriffe, die Suchiefe, und gegebenenfalls weitere Bedingungen, z. B. über die zunächst anzusprechende Suchmaschine, eine Zeitbegrenzung, eine Mengenbegrenzung, zu verwendende Protokolle (beispielsweise NNTP für News, FTP für Dateiarchive), oder Regelungen für zu la-

5

dende, eingebettete Bilder, Klänge, etc., enthält

Bei der erfindungsgemäßen Einrichning entsprechend der ersten Optimierungsstufe ist nun vorgesehen, daß ein entsprechender Agent innerhalb des Leitungsnetzes angeordnet ist. In einem bevorzugten Ausführungsbeispiel ist der Agent an der Nahtstelle zwischen einer Verbindung zu einem Leitungsnetz relativ hoher Übertragungshandbreite und einer Verbindung zu einem Leitungsnetz relativ niedriger Übertragungsbandbreite angeordnet, beispielsweise auf einem Server des jeweiligen Dienstanbieters.

Ein weiteres Ausführungsbeispiel des Agenten betrifft Übertragungsdienste, die auf einer Modemverbindung basieren. In einem solchen Szenario ist es vorteilhaft, deu Agenten im Bereich der Leitungsverbindung zwischen dem Endbenutzer und dem Modemdienst anzuordnen. Diese Anordnung hat insbesondere deu Vorteil, daß die durch die geringen Übertragungsraten einer Modemverbindung bedingten hohen Leitungskosten sehr effektiv minimiert werden können, da die vom Agenten zum Endbenutzer übertragenen Informationen durch den Agenten bereits in eine derart 20 kompakte Form gebracht werden, die möglichst geringe Übertragungskapazitäten erfordert.

Bei dem erfindungsgemäßen Verfahren und der Einrichtung kann weiterhin vorgesehen sein, daß die von dem Agenten bereitgestellten Nachsuchungsergebnisse dem Benutzer wiederum als recherchierbare Datenpakete bereitgestellt werden, in denen die - wie in der HTML (Hypertext Markup Language) Dokumentenbeschreibungssprache üblichen - "Hyperlinks" weiterhin enthalten sind. Dadurch wird heim Endbenutzer ein lokales "Surfen" in den übermittelten 30 Informationen ermöglicht, wobei die Nachteile der großen Antwortzeiten beim interaktiven Arbeiten mit dem Internet automatisch entfallen. Hyperlinks auf nicht bereitgestellte Dokumente werden dabei so verändert, daß sie wieder in das Internet zeigen und ein Anwender ohne Untwege direkt ins 35 Internet gelangt, um dort weitere, nicht durch die Suchkriterien erfaßte Dokumente zu lesen und gegebenenfalls vom Netz herunter zu laden.

Bei der Erfindung kann weiterhin vorgesehen sein, daß Filterfunktionen bereitgestellt werden, durch die der Umfang der vom Agenten aufgefundenen Informationen sinnvoll beschränkt werden kann.

Gemäß einem weiteren Ausführungsbeispiel ist eine Bandbreitenreservierung vorgesehen, mittels der die Auslastung der Übertragungsressourcen innerhalb des Informationsnetzes optimiert werden kann.

Darüber hinaus können die verfügbaren Übertragungskapszitäten sowohl zwischen dem Informationsnetz und dem Agenten als auch zwischen dem Agenten und dem Endbenutzer gemäß einem weiteren Ausführungsbeispiel dadurch besser genutzt werden, daß die vom Agenten erfaßten und an den Benutzer übertragenen Informationen mittels eines Filters mimimiert werden, dessen Parameter vom Benutzer bereits bei der Anforderung angegeben werden können.

Ferner kann vorgesehen sein, daß die vom Agenten zum SS Benutzer übermittelten Informationen vor der Übertragung zusätzlich komprimiert werden, um auch die Übertragungsressourcen zwischen diesen beiden optimal nutzen zu können. Diese Ausführungsform ist besonders vorteilhaft anwendhar bei einer Modemverbindung mit im allgemeinen 60 relativ geringen freien Übertragungskapazitäten zwischen dem Benutzer und dem Netzanbieter bzw. dem Agenten.

Die Anforderungen des Benutzers können in vorteilhafter Weise mittels eines (Auftrags-)Formulars an den Agenten weitergegeben werden, das die für den Hintergrund- bzw. 65 Stapelbetrieb erforderlichen Informationen enthält. Darin können vom Benutzer sowohl Kriterien für die anvisierten Informationen als auch die vorgepannten Parameter für die

D T------

Filterung der übertragenen Informationen angegeben warden. Die nachgesuchten Informationen können hierbei entweder in Form von Suchbegriffen oder als direkte Suchadressen (z. B. als URLs) eingegrenzt werden.

In einem weiteren Ausführungsbeispiel arbeitet der Agent mit einer oder mehteren im Informationsnetz angesiedelten Suchmaschinen zusammen, um beispielsweise Nachsuchungen besonders effizient gestalten zu können. Hierbei können auch regelmäßig verwendete Informationen bereits beim Agenten vorgespeichert sein (Cachebetrich). Insbesondere können Aufträge entsprechend einer Benutzeranforderung an mehrere Suchmuschinen parallel (gleichzeitig) erteilt werden. Dadurch kunn die Ausbeute der angeforderten Informationen deutlich erhöht werden und die Suche dadurch beschleunigt werden, daß die Nachsuchung bereits nach dem Eintreffen der ersten Informationen beim Agenten abgebrochen werden kann. Das Eintreffen von Informationen beim Agenten zu unterschiedlichen Zeitpunkten kann beispielsweise durch unterschiedliche Verarbeitungsgeschwindigkeiten der angesprochenen Suchmaschinen bedingt sein.

In einem weiteren Ausführungsbeispiel – entsprechend der zweiten Optimierungsstufe – kann vorgesehen sein, daß mindestens ein neuer Programmfaden generiert bzw. gestartet wird, sobald freie Bandbreiten verfligbar sind.

In einer bevorzugten Ausführungsform kann als ein weiteres Prozeßmittel ein Zeitplanungsmodul (Scheduler) vorgeschen sein, das in regelmäßigen Zeitabständen die verfügbaren Übertragungsbandbreiten überprüft und zum Zwecke der Genetierung neuer Programmfäden auf die anderen Prozeßmittel sowie den Pufferspeicher entsprechenden Zugriff hat.

Ferner kann vorgesehen sein, daß in dem Pufferspeicher auch Zusatzinformationen über die Erfassungstiefe der referenzierten Dokumente bei der Nachsuchung abgelegt sind, um insbesondere ein rechtzeitiges Abbrechen der Analyseund Nachsuchungsprozesse zu garantieren, die ohne derartige Abbruchkriterien endlos weiterlaufen würden.

Weiter können in dem Pufferspeicher sämtliche Kundenaufträge, insbesondere alle neu eingebenden Aufträge, zusammen mit etwa vorliegenden Filterbedingungen des jeweiligen Suchauftrags, in vorteilhafter Weise zwischengespeichert werden.

In einem besonders vorteilhaften Ausführungsbeispiel werden sämtliche für eine Implementierung der Erfindung erforderlichen Komponenten, insbesondere die den Kern einer Dokumentenanforderung betreffenden funktionellen Teile, in objekt-orientierter Technologie bereitgestellt.

Im folgenden Teil wird die Erfindung anhand von bevorzugten Ausführungsbeispielen näher erläutert. Im einzelnen zeigen

Fig. 1 cin bei der Erfindung zugrundegelegtes Informationsnetz nach dem Stand der Jechnik;

Fig. 2 cinc schematische Übersicht über den erfindungsgemäßen Dienst entsprechend einer ersten Optimierungsstufe;

Fig. 3 im Vergleich mit Fig. 2, eine entsprechende schematische Darstellung einer zweiten Optimierungsstufe gemäß der Erfindung:

Fig. 4 ein der Fig. 1 entsprechendes Diagramm, bei dem zusätzlich ein der vorliegenden Erfindung entsprechender Dienst zwischen dem Netz und einem Netzanbieter zwischengeschaltet ist;

Fig. 5 ein den Fig. 1 und 4 entsprechendes Diagramm, das ein weiteres Ausführungsbeispiel der vorliegenden Erfindung illustriert, bei dem der erfindungsgemäß vorgeschlagene Dienst beim Netzanbieter selbst angeordnet ist;

Fig. 6 eine gemäß der Erfindung im Hintergrund ab-

7

laufende Dokumentennachsuchung auf eine Benutzeranforderung hin;

Fig. 7a, 7b anhand eines Flußdiagramms den funktionellen Ablauf einer Auftragsbearbeitung bei einem Agenten entsprechend der Erfindung, sowie eine weitere Verarbeitung aufgrund von Referenzen zwischen vorliegenden Dokumenten;

Fig. 8 eine schematische Blockdarsteilung eines bevorzugten Ausführungsbeispiels der zweiten Optimierungssufe gemäß der Erfindung;

Fig. 9 eine schematischer Zeitverlauf der Erfassungs- und Analyseprozesse gemäß der zweiten Optimierungsstufe der Erfindung;

Fig. 10 ein exemplarisches Objektmodell des Agenten, bei dem die wesentlichen Klassen zur Auftragebearbeitung 15 dargestellt wurden (Beschreibung nach UML – Unified Modelling Language);

Fig. 11 eine bevorzugte Ausführungsform eines objektorientierten JobSchedulers gemäß der zweiten Optimierungsstufe der Erfindung; und

Fig. 12 ein zusammenfassendes detailliertes Interaktionsdiagramm einer Auftragsarbeitung gemäß der Erfindung.

Fig. 1 illustriert zunächst das der Erfindung zugrundeliegende Umfeld eines Informationsnetzes, hier dem Internet bei dem eine Reihe von Findbenutzern über einen Nerzan- 25 bicter Zugang zu dem Informationsnetz haben. Die jeweilige Situation ist dabei im wesentlichen durch zwei Übertragungsstrecken gekennzeichnet, zum einen die Übertragungsstrecke zwischen dem Netzanbieter und dem Internet, die im allgemeinen durch extreme Überlastung in Spitzen- 30 zeiten und eine extreme Unterbelastung zu anderen Zeiten charakterisiert ist, auf der anderen Seite die Einzelverbindungen zwischen den Endbenutzern und dem Netzanbieter, deren Übertragungseigenschaften oftmals konträr zueinander stehen. Gegenüber den Kommunikationsverbindungen 35 zwischen dem Netzenhieter und dem Internet sind die Leitungsverbindungen zwischen dem Netzanbieter und dem Endbeautzer typischerweise durch extreme Unterbelastungen zu Spitzenzeiten sowie weit unter den verfügbaren Bandbreiten liegende Datendurchsatzraten charakterisiert.

Anhand von Fig. 2 werden die beiden Optimierungsstufen des erfindungsgemäßen Dienstes zunächst gegenübergestellt. In der ersten Optimierungsstufe dient der vorgeschlagene Dienst insbesondere dazu, die Leitungsverbindung 1 zwischen dem Nerzanbieter und dem Endbenutzer dadurch 45 zu optimieren, daß die Leitung möglichst wenig frequentiert wird. Dies wird im Grundsatz dadurch erreicht, daß die Generierung von Benutzeranforderungen und deren Bearbeitung voneinander entkoppelt abgewickelt werden. Im Gegensatz dazu wird bei der zweiten Optimierungsstufe insbesondere die Leitungsverbindung zwischen dem Netzanbieter und dem Informationsnetz (z. B. dem Internet) optimiert. Diese Optimierung basiert auf dem Konzept, daß die in diesem Beispiel beim Netzanbieter angesiedelten Funktionscinheiten Aufträge bearbeiten und zeitlich parallel Anforde- 55 rungen an das Informationsnetz verschicken. Somit kann ein "Pool" von Dokumentenadressen im voraus generiert werden, der zu optimalen Leitungsbedingungen zum Informationsnetz sukzessive abgearbeitet werden kann. Damit wird erreicht, daß freie Übertragungskapazitäten sofort genutzt 60 werden können und nicht erst noch auf neue Dokumentenadressen aus den Analyseprozessen gewartet werden muß. Die im Pool abgelegten Aufträge können zudem priorisiert werden, beispielsweise kann Dokumenten ohne Bilder gegenüber Dokumenten mit Bilder der Vorrang gegeben wer- 65 den, oder kleine gegenüber großen Dokumenten bei der Bearbeitung der Anforderungen bevorzugt werden.

In Fig. 3 ist eine Ausführungsform der Erfindung darge-

stellt, bei der die bei beiden Optimierungsstufen erforderlichen Funktionselemente direkt beim Endbenutzer angesiedelt sind. Aufgrund der im folgenden noch ausführlich beschriebenen Eigenschaften des erfindungsgemäßen Dienstes, kommen die Vorteile bei der Leitungsoptimierung be-

rcits hier zum Tragen.

Der vorliegenden Erfindung liegt nun in der ersten Optimierungssuife das Konzept zugrunde, einen Agenten bereitzustellen, der dem jeweiligen Endbenutzer das Durchsuchen des Informationsnetzes und das Aufsammeln der angeforderren Informationen sowie deren Vermittlung an den Endbenutzer abnimmt. Die Anforderungen des Benutzers werden dabei von dem Agenten in Form einer Hintergrundbzw. Stapelverarbeitung offline vom Benutzer durchgeführt. Die Erfindung ermöglicht dabei, das Durchsuchen und Einsammeln von Informationen in dem Informationsnetz nach einem Zeitplan durchzustihren, bei dem die Ausführung der Benutzeranforderungen erst zu einem Zeitpunkt oder in einer Zeitspanne erfolgt, die erst im Anschluß an das Erstellen des Anforderungsauftrags durch den Benutzer liegt. Die im Hintergrund ablaufende Stapelverarbeitung wird dabei vorzugsweise zu Zeiten durchgeführt, in denen das Informationsnetz zumindest nicht voll ausgelastet ist. Durch dieses Verfahren wird zum einen die Auslastung der in dem Informationsnetz fließenden Datenströme optimiert und zum anderen Verkehrsspitzen bei der Übertragung deutlich reduziert. Durch Reduzieren der erforderlichen Übertragungsbandbreite für den Zugriff auf das Informationsnetz werden lerzilich auch die Betriebskosten gesenkt.

Im Falle einer Wählverbindung ergibt sieh ein Kostenvorteil bereits aus der der Erfindung zugrundeliegenden zeitlichen- und räumlichen Entkopplung zwischen dem Benutzer und der Auftragsbearbeitung durch den Agenten. Nachdem der Benutzer seine Anforderung an den Agenten übermittelt hat, kann nämlich die Wählverbindung zwischen beiden unterbrochen werden. Eine neue Wählverbindung muß erst dann wieder aufgebaut werden, wenn die nach abgeschlossener Auftragsbearbeitung beim Agenten vorliegenden gesammelten Informationen an den Benutzer übermittelt werden sollen. Der hierbei entstehende Kostenvorteil ist somit darin begründet, daß die Notwendigkeit für das Aufrechterhalten einer Wählverbindung von der Abgabe einer Anforderung bis zur Übertragung der gesuchten Informationen an den Benutzer nunmehr entfällt.

Die genannte Entkopplung ermöglicht zudem ein gegentlber dem Stand der Technik wesentlich verbessertes zeitliches Konnektivitätsverhalten von mobilen Systemen, z. B. Laptops, zu den genannten Informationssystemen. Nachdem auch hier ein Suchauftrag an den Agenten erteilt worden ist, kann das mobile System vollständig vom Informationsnetz getrennt werden. Erst zu einem späteren Zeitpunkt, nachdem mit der Erledigung des Auftrags seitens des Agenten gerechnet werden kann, kann die Verbindung zu dem Informationsnetz erneut aufgebaut werden und die Informationen vom Agenten zum mobilen System übertragen werden. Damit wird unter anderem die Mobilität dieser Systeme entscheidend verbessert.

Im Umgang mit dem Internet ist der Endbenutzer gegenwärtig darauf angewiesen, das Informationsnetz nach den
gesuchten Informationen online und interaktiv zu durchsuchen. In einem ersten Schritt wird gewöhnlich eine sogenannte Suchmaschine angesprochen, um sich über sämtliche
auf dem anvisierten Gebiet im Internet vorliegenden Dokumente einen Überblick zu verschaffen. Mittels der in
HTML-Dokumenten bereitgestellten Hyperlinks kann nun
ausgehend von den seitens der Suchmaschine zunächst bereitgestellten Informationen weitere noch detailliertere Informationen von den jeweiligen Ursprungsservern abgenu-

9

fen werden. Dieser im allgemeinen mehtstufige Prozeß bedeutet einen enormen Zeitaufwand, um schließlich das gewünschte Dokument zu erhalten, und ist somit im geschäftlichen Bereich nahezu nicht durchführbar.

Der arfindungsgemäß vorgeschlagene Dienst führt nun an 5 Stelle des Endbenutzers die beschriebenen Suchschritte eigenständig durch und übermittelt erst am Ende eines Suchvorganges die gesamten Informationen in Form eines einzelnen Pakets an den Benutzer. Da dieses Informationspaket den ursprünglichen Hyperlinks entsprechende Referenzen 10 bereitstellt, steht es dem Benutzer frei, das nunmehr begrenzte Informationspaket lokal weiter nach noch spezielleren Informationen zu durchsuchen.

Im Hinblick auf den ebenfalls zu optimierenden Zugang des Netzanbieters zu dem Informationsnetz ist es besonders 15 vorteilhaft, den erfindungsgemäßen Dienst in der Nübe des Netzanbicters anzusiedeln. In dem in Fig. 4 dargestellten ersten Ausführungsbeispiel der Erfindung ist dieser Dienst innerhalb des Übertragungsleitungsbereichs zwischen dem Internet und dem Netzanbieter angeordnet. Es sind allerdings 20 auch andere Implementierungswege vorstellbar, bei denen die Steuerungsfunktionen entsprechend der vorbeschriebenen Funktionalität z.B., durch eine spezialisierte Hardware realisiert sind. Der Dienst sammelt völlig autonom die von dem jeweiligen Benutzer gewünschten Informationen und 25 übermittelt entweder die aufgefundenen Informationen direkt an den Benutzer oder speichert sie zwischen, so daß die Informationen für den Endbenutzer auf Abruf zur Verfügung stehen. In beiden Fällen wird jedenfalls die Verbindung zwischen dem Benutzer und dem Netzanbieter mit na- 30 ren. hezu optimaler Übertragungsrate betrieben, da sämtliche Daten nach dem Boenden der Stapolverarbeitung beim Netzanbicter verfügbar sind und keinerlei Daten tiber das Internet online abgerufen werden müssen. Da der vorgeschlagene Dienst eine eingehendere Terminierung der zu be- 35 arbeitenden Suchaufträge ermöglicht, verhindert der vorgeschlagene Dienst schr effizient, daß viele Benutzer zur selben Zeit online Zugang zu dem Internet haben, so daß es nicht weiter erforderlich ist, die bisher notwendige Vielzahl von gleichzeitigen Zugriffen zu dem Netz bereitzustellen. 40

Es wird an dieser Stelle hervorgehoben, daß der Dienst gemäß der Erfindung zwischen dem Client und dem Server, und nicht – wie beispielsweise in den in der Beschreibungseinleitung zitierten Europäischen Patentanmeldungen – hinter dem Server plaziert ist. Dartüber hinaus muß entweder 45 dem Server oder einem Server-Skript die Existenz des Dienstes (Agenten) bekannt sein, da dieser aktiv abgefragt werden muß. Der hier vorgestellte Agent ist nur dem Client bekannt und tritt anderen Servern gegenüber auch nur als gewöhnlicher Client, z. B. als ein Web Browser, auf.

Gegenüber dem in Fig. 4 dargestellten Ausführungsbeispiel kaun es auch zweckmäßig sein, den erfindungsgemäßen Dienst heim Netzanbieter selbst bereitzustellen, da der Anbicter die hesseren Ausgangsbedingungen für eine Optimierung des Netzwerkverkehrs vorliegen hat. Ein entsprechendes Ausführungsbeispiel ist in Fig. 5 dargestellt. Bei diesem Ausführungsbeispiel sind das für den vorgeschlagenen Dienst erforderliche Kontrollprogramm sowie die erforderliche Datenbank bzw. der Zwischenspeicher beim Internetanbieter selbst, z. B. auf einem Server des Netzanbieters, 60 zurufen.

Das im Internet (oder World Wide Web) am meisten verwendete Übertragungsprotokoll ist das sogenannte HTTP-Protokoll (Hypertext Transfer Protocol). Für gewöhnlich wird dieses Protokoll zur Übertragung von HTML-Dokumenten verwendet. Dieses Übertragungsprotokoll eignet sich jedoch auch dazu, Informationen jeglicher Art zu übertragen, die eine sogenannte URL (Uniform Resource Locatragen, die eine sogenannte URL (Uniform Resource Locatragen, die eine sogenannte URL (Uniform Resource Locatragen)

10

tor) aufweisen. Hypertextdokumente beinhalten Text, sogenannte "links", und die in die jeweiligen Dokumente eingebeuten Daten. Diese Dokumente können daher als ein "Dokumentenuetz" betrachtet werden, bei dem Dokumente auf andere Dokumente verweisen und bei dem die Dokumente nahezu sämtliche Informationsarten wie Bild-, Ton- oder Textinformationen beinhalten können.

Die in einem Dokument eingebetteten Daten werden zunächst mit dem jeweiligen Dokument zusammen präsentiert, jedoch erfordert ein Zugriff auf diese Daten jeweils
eine neue HTTP-Anforderung (-Auftrag), um diese Daten
zu laden. Referenzierte Dokumente können ihrerseits unter
Verwendung des HTTP-Protokolls über das Netz übertragen
werden. Ein HTTP-Webserver kann nun zu allen bereitgestellten Informationen den Dateityp ("Content Type") übermitteln.

Gemäß einem weiteren Ausführungsbeispiel des erfindungsgemäßen Dienstes (Agenten) ist vorgeschen, daß der Benutzer (Client) vor dem Beginn der eigentlichen Nachsuchung ein Formular ansfüllt, in dem der Suchauftrag im einzelnen spezifiziert ist. Dieses Formular kann z. B. von einem Web Server bereitgestellt werden, der mit dem Agenten in Verbindung steht. In dem Formular kann nun entweder eine direkte Internetadresse (URL) angegeben werden, sofen der Benutzer bereits über eine Adresse zu den gesuchten Informationen verfügt, oder aber ein oder mehrere, gegebenenfalls logisch verknüpfte, Suchbegriffe. Im Falle von Verwendeten Suchbegriffen wird der Agent zunächst miodestens eine im Internet angesiedelte Suchmaschine konsultieren.

Zur Eingreuzung der insgesamt aufgefundenen Informahonen zu dem avisierten Fachgebiet sowie zu Zwecken der
Kostenminimierung kann in dem Auftragsformular bereits
eine maximale Obergrenze der später an den Benutzer übermittelten Treffer angegeben werden, z. B. die jeweils ersten
zehn Treffer zu einem Sachgebiet, Ferner kann die Suchtiefe
für die Recherche angegeben werden, d. h. eine Obergreuze
dafür gesetzt werden, wie oft der Server "Links" in Dokumenten weiterverfolgt oder Unterverzeichnisse in FTP(File Trausfer Protocol) Archiven. Darüber hinaus läßt sich
die Informationsflut weiter einschränken durch Limitierung
der Suchzeit bzw. Zeit für das Herunterladen von Informationen vom Netz sowie durch Limitierung des Informationsaufkommens selbst.

Optional können das von dem Agenten bei der Recherche zu benutzende Protokoll sowie die gesuchten Medien- und Datentypen genauer angegeben werden. So kann oftmals auf die Übermitung von Bilddaten verzichtet werden, für deten Übertragung relativ große Übertragungskapazitäten erforderlich sind. Die genannten Protokolle betreffen zum einen die in Hypertextdokumenten meist enthaltenen Links zu anderen Dokumenten bzw. Webseiten. Diese Links können HTTP- oder FTP-Links sein, wobei HTTP-Links rekursiv mit anderen HTTP-Links verknüpft sein können. Zum anderen kann bei den Protokollen Berücksichtigung finden, daß nicht alle Fundstellen im weltweiten Informationsnetz HTTP-basiert sind. Die im Rahmen der Erfindung verwendeten, aktuelle Tagesnachrichten von einem News-Server abzurufen.

Im Gegensaiz zu HTTP-Dokumenten sind FTP-Dokumente nicht weiter recherchierbar bzw. können Nachsuchungen nicht innerhalb von FTP-Archiven gestartet werden, da weder Typ noch Inhalt der Dateien vorab bekannt sind.

Eine exemplarische Anwendung der Erfindung im Bereich einer Dokumenten-Nachsuchung wird nun anhand von Fig. 6 näher erläutert. In dem zugrundeliegenden Suchauf-



11

12

trag wird in diesem Beispiel unter anderem angegeben, daß die Suche unter Berücksichtigung von HTTP- und FTP-Links etfolgen soll, bei einer Suchtiefe von "zwei" bei der nur Dokumente bis zur zweiten Generatiov (d. h. insgesamt zwei Ebenen in der Netzstruktur) berücksichtigt werden. Ferner sollen lediglich Dokumente des Medientyps "HTML" und "Postscript" nachgesucht werden.

Sämtliche der aus dem Netz extrahierten Informationen werden zunächst in einen Ordner zwischengespeichert. Die in dem jeweiligen Dokument enthaltenen Referenzen auf 10 andere Dokumente oder eingebedtete Dateien werden dabei so umgeschrieben, daß sie auf die lokalen Kopien im Ordner zeigen. Bei nicht vom Netz heruntergelsdenen Dateien, z. B. solchen außerhalb der angegebenen Suchtiefe, werden die ursprünglichen Links beibehalten, um dem Auftraggeber 15 (Endbenutzer) weitere noch tiefergehenden Recherchen, auf diese Links aufbauend, zu ermöglichen.

Das in Fig. 7a dargestellte Flußdiagramms zeigt den funktionellen Ablauf einer Auftragsbearbeitung durch einen Agenten gemäß der Erfindung. Die beim Agenten eintreffenden Suchaufträge werden zunächst in eine Auftragsliste gespeichen. Für jeden der derzeit ausgeführten Austräge werden in dem Ausführungsbeispiel die gezeigten Bearbeitungsschritte durchlaufen. Für den Fall, daß ein Auftrag bereits zu Ende geführt wurde und damit abgeschlossen wer- 25 den kann, wird der Auftrag zunächst aus der Liste der aktiven Aufträge entfern. Die entsprechend dem jeweiligen Auftrag erfaßten Informationen werden gleichzeitig zwischengespeichert. In diesem Ausführungsbeispiel werden dann die gespeicherten Nachsuchungsergebnisse auf Abruf 30 des Auftraggebers hin vom Agenten an den Auftraggeber übermittelt. Zum Zwecke einer Optimierung der Kommunikationsverbindung zwischen dem Agenten und dem Benutzer ist in diesem Beispiel weiter vorgesehen, daß die auf der Agentenseite erledigten Aufträge zuvor in eine Abhol- 35 schlange eingereiht werden.

Solange ein Auftrag nicht abgeschlossen werden kann, werden die im rechten Teil des Diagramms gezeigten Schritte durchlaufen. Zunächst wird für jeden Teilaustrag geprüft, ob die für die Bearbeitung des Teilauftrags erforderliche Bandbreite verfügber ist. Debei werden bereits die für weitere interaktive Prozesse vorgesehenen Reserven berücksichtigt. Weiter werden geprüft, ob die Maximalwerte der für den Agenten bzw. Auftrag verfügbaren Programmfäden (Threads) und die in dem Anforderungsprofil näher spezifizierten Filter wie z.B. maximale Bearbeitungszeit oder Maximalmenge der erfaßten Informationen noch einen weiteren Bearbeitungs-(Such-)Prozeß zulassen. Abhängig von dieser Bedingung wird der Suchauftrag entweder abgebrochen oder ein neuer Programmfaden gestartet, der das gesuchte Dokument beschafft, Gleichzeitig wird dieses Dokument aus einer Dokumentenliste enrfernt.

Hinsichtlich der Verarbeitung der Suchaufträge kommt dem Agenten folgeode weitere Aufgabe zu: Ein bereits gestarteter Informationstransfer vom Netz zum Zwischenspeicher des Agenten darf nicht unterbrochen werden, da dies zu Datenverlusten führt und einen Neustart der gesamten Datenübertragung erfordem würde. Daher werden keine neuen Erfassungsaufträge gestartet, solange nicht die erforderlichen Übertragungskapazitäten verfügbar sind. Der Agent 60 ermittelt somit regelmäßig die Jeweils aktuelle Situation bei den verfügbaren Bandbreiten und entscheidet dann, ob ein weiteres Dokument angefordert werden kann (entkoppelt in einem eigenen Programmfaden), ohne die interaktive Arbeit anderer Kunden zu geführden.

Der Ablauf des für die Dokumentenbeschaffung gestarteten Programmfadens wird nun an dem in Fig. 7b gezeigten Flußdiagramm näher verdeutlicht. Sofem ein vorliegendes

Dokument keine Referenzen auf andere Dokumente aufweist, wird das Dokument zum Zwecke der vorreilhaften Übermittlung vom Agenten zum Auftraggeber zunächst komprimiert und danach einem etwa bestehenden Gesamtarchiv hinzugefügt, Im Falle des Vorliegens von Referenzen, speziell beim Vorliegen noch nicht bearbeiteter Referenzen, wird zunächst eine Beschreibung des jeweils referenzierten Dokuments angefordert. Ergibt sich nun aus der Dokumentenbeschreibung, daß dieses Dokument nicht den vorliegenden Filterbedingungen gemäß dem Anforderungsprofil gentigt, wird die Referenz weiterhin extern berücksichtigt, d. h. eine evel relative Adresse auf die jeweilige externe Quelle (z. B. URL) im Internet umgeschrieben. Genügt jedoch das Dokument den Filterbedingungen, dann wird die vorliegende Hyperlink in eine Referenz auf das Dokument, welches dann lokal verfügbar gemacht wird (lokale Quelle), umgeschrieben. Zudem wird die Dokumentenreferenz in die Dokumentenliste des jeweiligen Auftrags eingetragen, um das entsprechende Dokument auch für den Anwender verfligbar zu machen.

In einem weiteren (nicht gezeigten) Ausführungsbeispiel der Erfindung führt der Agent eine dynamische Reservierung von Bandbreiten durch. Hier liegt die Erkenntnis zugrunde, daß eine Unterbrechung des Prozesses des Hexunterladens von Informationen aus den bereits genannten Gründen nachteilig ist und es daher zweckmäßig ist, die verfügbaren Leitungsressoureen nicht ständig am oberen Limit zu betreiben, sondern Leitungsreserven bereitzustellen, die für neu zu stattende Suchprozesse oder hei Erhöhung des Datendurchsatzea bei laufenden Prozessen eingesetzt werden können. Auch beim Herunterladen sehr großer zusammenhängender Dateien werden solche Reserven benötigt, da sich hier eine Unterbrechung besonders negativ auswirken würde. Die verfügbaren Bandbreiten sind in einem gewissen Rahmen vorherschbar, da änderude Nutzungsgepflogenheiten einzelner Internetbenutzer aufgrund der breiten Masse aller Benutzer sich statistisch nur relativ gering auswirken. Zudem ändert sich der Nutzungshabitus der breiten Internetklientel mit der Zeit nur relativ gering.

Aus dem vergangenen und dem aktuellen Benutzerverhalten läßt sich die Bandbreitennutzung für den interaktiven Verkehr in nächster Zukunft ableiten. Die Differenz zwischen dieser zu erwartenden Last und der maximal verfügbaren Bandbreite bestimmt die freie Bandbreite für den Hintergrundbetrieb bzw. den Stapelbetrieb des Agenten. Ein Teil dieser freien Bandbreite wird hiervon jedoch nicht verwender. Dieser Teil richtet sich nach dem zu erwartenden zukünftigen Benutzerverhalten und den zu erwartenden Änderungen im Datendurchsatz. So steigt die freigehaltene Bandbreite, wenn mit mehr interaktiv arbeitenden Kunden zu rechnen ist, und fällt, wenn die Anzahl konstant bleiben oder fallen wird. Die Reserve fällt auch, wonn zu erwarten ist, daß Verbindungen in nächster Zeit mehr umsetzen können, weil eventuell in anderen Gebieten weniger Verkehr herrschen wird (z. B. nachts in den USA). Im umgekehrten Fall steigt die Reserve entsprechend.

Aus der vorhergehenden Beschreibung wird deutlich, daß mit Hilfe des vorgeschlagenen Dienstes (Agenten) auch die Leitungsverbindung zwischen dem Netzanbieter und dem Budbenutzer (Client) in einem optimalen Kosten-/Nutzungs-Fenster betrieben werden kann, und somit für beide, den Netzanbieter und den Budbenutzer, erhebliche Betriebskosten für die Unterhaltung von Leitungsverbindungen eingespart werden können.

Fig. 8 zeigt nun eine schematische Blockdarstellung eines bevorzugten Ausführungsbeispiels der Erfindung gemäß der zweiten Optimierungsstufe. Eine URL-Liste (Pool) wird – wie bereits erwähnt – vom Scheduler für das Aufsetzen

13

neuer Erfassungs- und Analyscprozesse genutzt. Hierbei operieren die Analyseprozesse und der Scheduler getrennt voneinander. Sie kommunizieren lediglich indirekt über die URI-Liste, aus der sich der Scheduler immer dann eine URL cines noch anzufordernden Dokuments herausgreift, wenn freie Bandbreite verfügbar ist. Neue Adressen werden von den Dokumentenanalyseprozessen kontinuierlich hinzugefügt, sie bedingen jedoch keine direkte Interaktion mit dem Scheduler und damit auch keine (norwendig) unmittelbarc Weiterverarbeitung der Adressen, Vielmehr startet der 10 Scheduler neue Erfassungsprozesse erst dann, wenn die Bedingung der freien Bandbreite exfüllt ist. Sollte der Scheduler nicht rechtzeitig in der Lage sein, das Dokument vor Auftragsabschluß anzufordern, wird es aus der URL-Liste entfernt und der Auftrag abgeschlossen. Die URL-Liste ist 15 bevorzugt als FIFO-Liste (First-In-l'arst-Out) organisiert, um zeitlich früher erfaßte Adressen vor anderen Adressen zu priorisieren.

Fig. 9 zeigt schematisch einen Zeitverlauf der Erfassungs- und Analyseprozesse gemäß der zweiten Optimie- zungsstufe der Erfindung. Nach Abschluß einer Dokumentenerfassung wird das Dokument auf etwa enthaltene Referenzen zu anderen Dokumenten hin analysiert und bei Vorliegen solcher Referenzen die ermittelten URLs in den URL-Pool abgelegt. Im Falle verfügbater Bandbreiten werden nun entsprechend den URLs weitere "Tochterprozesse" (Threads) geneniert, die sich wiederum aus einer Dokumentenerfassung und einem Analyseprozeß zusammensetzen. Die Generierung von Tochterprozessen endet dann mit der vonn Auftraggeber angegebenen Suchtiefe, wie oben bereits 30 beschrieben wurde.

In Fig. 10 ist nun eine bevorzugte Ausführungsform des JobSchedulers gemäß der zweiten Optimierungsstufe der Erfindung in objekt-orientierter Implementierung dargestellt. Aufträge, in denen bestimmte Dokumente über URLs 35 angefordert werden (Dokumentenerfassungsaufträge), werden direkt in ein Objekt der Klasse "Job" umgewandelt und dem JobScheduler übergeben. Ist der Auftrag eine Suchanfrage (Dokumentennachsuchungsauftrag), dann werden innorhalb des die Anfrage annehmenden Programmfadens, 40 parallel und asynchron vom Agenten, mehrere Suchmaschinen befragt und die zurückgelieferten Adressen in die URL-Liste eingetragen. Danach wird entsprochend der vorbeschriebenen Standardprozedur bei Dokumentenerfassungsausträgen weiterverfahren, d. h. mit den gefundenen Adres- 45 sen ein Objekt der Klasse "Job" erzeugt und dem JobScheduler-Objekt übergeben. Aufträge werden ihrer Priorität (z. B. Auftragsabschlußzeitpunkt oder mögliche Gebührenklasse) each sortiert und bearbeitet. Das JobScheduler-Objekt informiert Auftragsabschluß das WebAgent-Objekt 50 über den abgeschlossenen Auftrag. Das WebAgent-Objekt kann im folgenden z. B. den Anwender über den Auftragsabschluß über eine E-Mail in Kenntnis setzen oder ihm die Daten durch einen FTP-Upload zukommen lassen.

Um das System nicht durch permanente Zustandsabfragen (polling) zu belasten, sind die Funktionselemente des erfindungsgemäßen Dienstes, insbesondere der JobScheduler, ereigtuisgesteuert. Der JobScheduler fordert daher erst bei Erhalt eines Aufwecksignals, das füblicherweise für einen neuen Auftrag oder bei Beendigung einer Dokumentenerfassung gesendet wird, anbängige Prozesse (Objekte der Klasse "Job") dazu auf, ihren aktuellen Zustand zurückzumelden. Den dringlichsten Aufträgen erlaubt der Scheduler – ausreichend Bandbreite vorausgesetzt – das Starten eines oder mehrerer Programmfäden (Threads). Hierfür wird für jeden Programmfaden ein Objekt der Klasse "Thread" erzeugt. Jedes dieser zunächst eigenschaftslosen Objekte wird über ein Objekt der Klasse "Job::ThreadData" an das Job-

14

Objekt gekoppell. Dies ermöglicht einen Zugriff auf die Austragsdaten. Kern dieser Daten ist eine Dokumentenadresse im URL-Format. Die URL, wird ferner in einem Objekt der Klasse "WebRequest" abgelegt.

Eine erste Aktion des neuen Programmfadens ist die Beschaffung des (der) referenzierten Dokuments (Dokumente) über eine Klasse "Retriever". Zur Kommunikation über TCP/IP (Transmission Control Protocol/Internet Protocol-Standard) instanziiert diese Klasse ein Objekt der Klasse "Regulated Transceiver". Das Retriever-Objekt liefert die Daten des Dokuments und - in Abhängigkeit von dem jeweils verwendeten Dienstprotokoll - ein Objekt der Klasse "HTTPDocumentInfo" oder "FTPDocumentInfo" zurück. Handelt es sich um ein über das HTTP-Protokoll (Hypertext Transfer Protocol) geladenes Dokument, so kann auch auf den Medientyp zurückgegriffen werden. In einem solchen Fall überprüft der Programmfaden, ob es sich um ein HTML-Dokument handelt und instanziiert mit den Dokumentendaien ein Objekt der Klasse "HTMLDocument". Diese Klasse bietet die Möglichkeiten zum Durchsuchen des Dokuments nach Hyperlinks. Das Thread-Objekt überprüft alle referenzierten Dokumente auf ihre Eigenschaften und entscheidet, ob das referenzierte Dokument der bereits existierenden URL-Liste hinzugefügt werden soll oder nicht. Auswahlkriterien sind die Benutzeroptionen, wie beispielsweise Größe und Typ der Datei. Terminiert der Programmfaden, so sendet dieser dem JobScheduler-Objekt ein Aufwecksignal. Ist die URL-Liste eines Auftrags leer, so ist der Auftrag abgeschlossen und der JobScheduler entfernt den Auftrag aus der Liste aktiver Aufträge.

Fig. 11 zeigt den internen Ablauf næchdem der JobScheduler ein Aufwecksignal erhalten hat (1). Er sichert sich (2) über eine Semaphore den ausschlicklichen Zugriff auf alle Datenstrukturen. Dies ist notwendig, da der JobScheduler auch aus anderen Programmfäden heraus angesprochen werden kann, z. B. aus Objekten der Klasse "WebAgent" oder der Klasse "Job". Nachdem er einen sicheren Zugriff erlangt hat, befragt (3) er die zu bearbeitenden Aufträge nach ihrem Zustand, meldet etwa abgeschlossene Aufträge an das WebAgent-Objekt (A4, A4.1) weiter, oder läßt ein Job-Objekt neue Programmfäden starten (B5, B5.1), wenn ausreichend Bandhreite verfügbar ist (B4). Abschließend gibt er die Semaphore wieder frei (6) und wartet (1) erneut auf ein Aufwecksignal.

Ein exemplarisches Interaktionsdiagramm zur Illustration des Ablaufs einer Auftragsarbeitung gemäß der Erfindung ist in Fig. 12 dargestellt. Der Anwender (Auftraggeber) übersendet (1) zunächst dem Agenten einen Auftrag sowie entsprechende Auftragsoptionen. Der Agent erzeugt daraus ein Job-Objekt (1.1) und informiert (1.2) den Scheduler über dieses Objekt. Der Scheduler fordent dann das Job-Objekt auf – in Abhängigkeit von der jeweils verfligbaren Bandbreite – Programmfäden zur Dokumentenerfassung zu starten (1.2.1, 1.2.2, 1.2.3, und später 1.2.5). Der Auftrag startet (1.2.1.1, 1.2.2.1, 1.2.3.1, 1.2.5.1) diese Programmfäden und

hat weiter keine Koutrolle mehr tiber sie. Die Programmfäden melden sich kurz vor der Terminierung beim Scheduler und teilen ihm ihren Abschluß mit (1.2.4, 1.2.6, 1.2.7, 1.2.8). Der Scheduler erkennt, daß keine weiteren Dokumente mehr geladen werden sollen, erklärt somit dem Agenten den Abschluß des Auftrags (1.3) und geht wieder in Wartestellung. Der Agent startet einen Programmfaden (1.4), der über ein Mail-Objekt (1.4.1) dem Anwender mitteilt (1.4.1.1), daß der Auftrag abgeschlossen wurde. Der Agent wird daraufhin nur noch für die Löschung des Auftrags angesprochen (2). Diese Löschung (2.1) bedingt gleichzeitig auch die Zerstörung des Job-Objekts (2.2).

15

#### Patentansprüche

- 1. Verfahren zum Nachsuchen und Erfassen von Informationen in einem Informationsnetz entsprechend einer Anforderung eines Benutzers, und zum Übermitteln dieser Informationen an den Benutzer, wobei das Informationsnetz mindestens einen Informationen bereitstellenden Netzknoten aufweist, dadurch gekennzeichnet, daß die Anforderung des Benutzers zunüchst an einen Agenten übermittelt wird, der die Anforderung, entkoppelt vom Benutzer, im Informationsnetz ausführt.
- Verfahren nuch Anspruch 1, bei dem die angeforderten Informationen nicht im voraus in dem Informationsnetz lokalisierbar sind.
- Verfahren nach Anspruch 1 oder 2, bei dem der Benutzer mittels eines Netzversorgers Zugang zu dem Informationsnetz erfährt, dadurch gekennzeichnet, daß der Agent bei dem Netzversorger angeordnet wird.
- 4. Verfahren nach Anspruch 1 oder 2, bei dem der Benutzer mittels einer Kopplungseinrichtung direkt mit
  dem Informationsnetz kommuniziert, dadurch gekennzeichnet, daß der Agent als ein eigenständiger Dienst
  im Informationsnetz realisiert wird.
- 5. Verfahren nach Anspruch 1 oder 2, bei dem der Bonutzer innerhalb eines betriebsinternen Netzwerks angesiedelt ist, wobei das betriebsinterne Netzwerk mit
  dem Informationsnetz in Verbindung steht, dadurch gekennzeichnet, daß der Agent an der Nahtstelle der Verbindung zwischen dem betriebsinternen Netzwerk und 30
  dem Informationsnetz angeordnet wird.
- Verfahren nach einem der vorhergehenden Ansprüche, dadurch gekennzeichnet, daß der Agent die Anforderung zu Zeiten geringer Netzauslastung des Informationsnetzes ausführt.
- 7. Verfahren nach Anspruch 6, dadurch gekennzeichnet, daß der Agent vor dem Übertragen von Informationen eine Bandbreitenreservierung für zusätzlichen interaktiven Informationsverkehr im Informationsnetz vornimmt.
- 8. Verfahren nach einem der vorhergehenden Ansprüche, dadurch gekennzeichnet, daß die vom Agenten bereitgestellten Informationen vor der jeweiligen Übertragung an den Benutzer komprimiert werden.
- Verfahren nach einem der vorhergehenden Ansprüche, dadurch gekennzeichnet, daß die vom Agenten bereitgestellten Informationen entsprechend einem Anforderungsprofil gefiltert werden und nur die gefilterten Informationen an den Benutzer übertragen werden,
- Verfahren nach einem der vorhetgehenden An- 50 sprüche, dadurch gekennzeichnet, daß der Benutzer die Anforderung mittels eines Formulars an den Agenten weitergibt.
- 11. Verfahren nach einem der vorhergehenden Ansprüche, insbesondere zur Anwendung im World Wide 55 Web (WWW), in dem Hyperlinks für das Dokumentenarchiv des Informationsnetzes verwendet werden, dadureb gekennzeichnet, daß der Agent bei den an den Benutzer übermüttelten Informationen die vorhandenen Hyperlinks dahingehend verändert, daß auf lokal beim 60 Benutzer vorliegende Dokumente verwiesen wird.
- 12. Verfahren nach einem der vorhergehenden Ansprüche, insbesondere zur Anwendung im World Wide Web (WWW), bei dem mindestens zwei Suchmaschiden vorgesehen sind, dadurch gekennzeichnet, daß zu 65 einer Benutzeranforderung parallel mindestens zwei Suchaufträge an zwei oder mehrere unterschiedliche Suchmaschinen übermittelt werden.

16

- 13. Verfahren nach Anspruch 12, dadurch gekennzeichnet, daß die zu der Benutzeranforderung erfaßten Informationen von den Suchmaschinen an den Agenten parallel übermittelt werden.
- 14. Einrichtung zum Durchsuchen eines Informationsnetzes nach von einem Benutzer angeforderten Informationen und zum Übermitteln der erfaßten Informationen an den Benutzer, wobei das Informationsnetz mindestens einen Informationen bereitstellenden Netzknoten aufweist.

gekennzeichner durch

mindestens einen Agenten zum Ausführen von Benutzeranforderungen in dem Informationsnetz;

erste Kommunikstionsmittel zwischen dem Benutzer und dem Agenten;

zweite Kommunikationsmittel zwischen dem Agenten und dem Informationsnetz;

Speichermittel zum Speichern der über die ersten Kommunikationsmittel an den Agenten übermittelten Benutzeranforderungen sowie der vom Agenten über die zweiten Kommunikationsmittel erfaßten Informationen:

Prozeßmittel zum vom Benutzer entkoppelten Ausführen der Benutzeranforderungen über die zweiten Kommunikationsmittel.

- 15. Einrichtung nach Anspruch 14, gekennzeichnet durch Mittel zur Übermittlung der erfaßten Informationen vom Agenten an den Benutzer auf eine Benutzeranforderung bin.
- 16. Einrichtung mach Anspruch 14 oder 15, bei dem der Benutzer mittels eines Netzversorgers Zugang zu dem Informationsnetz erfährt, dadurch gekennzeichnet, daß der Agent bei dem Netzversorger angeordnet ist.
- 17. Einrichtung usch Anspruch 14 oder 15, bei dem der Benutzer mittels einer Kopplungseinrichtung direkt mit dem Informationsnetz kommuniziert, dadurch gekennzeichnet, daß der Agent als ein eigenständiger Dienst im Informationsnetz realisiert ist.
- 18. Einrichtung nach Anspruch 14 oder 15, wobei der Benutzer innerhalb eines betriebsinternen Netzwerks angesiedelt ist, und wobei das betriebsinterne Netzwerk mit dem Informationsnetz in Verbindung steht, dadurch gekennzeichnet, daß der Agent an der Nahrstelle der Verbindung zwischen dem betriebsinternen Netzwerk und dem Informationsnetz angeordnet ist.
- 19. Einrichtung nach einem der Ansprüche 14 bis 18, dadurch gekennzeichnet, daß der Agent Mittel zur Optimierung der Bandbreiten für die Informationsübertragung in Abhängigkeit von den jeweils vorliegenden Übertragungskapazitäten aufweist.
- 20. Einrichtung nach Anspruch 19, dadurch gekennzeichnet, daß der Agent Mittel zur Reservierung von Bandhreiten für zusätzlichen interaktiven Informationsverkehr im Informationsnetz aufweist.
- 21. Einrichtung nach einem der Ansprüche 14 bis 20, dadurch gekennzeichnet, daß der Agent Mittel zum Komprimieren der an den Bevutzer übertragenen Informationen aufweist.
- 22. Einrichtung nach einem der Ansprüche 14 bis 21, dadurch gekennzeichnet, daß der Agent Mittel zur Filterung der vom Agenten bereitgestellten Informationen aufweist, mittels derer die an den Benutzer übertragenen Informationen entsprechend einem Anforderungsprofil gefiltert werden.
- 23. Einrichtung nach einem der Ansprüche 14 bis 22, gekennzeichnet durch ein Formular zur Überminlung der Benutzeranforderungen vom Benutzer an den

17

24. Einrichtung nach einem der Ansprüche 14 bis 23, insbesondere zur Anwendung im World Wide Web (WWW), in dem Hyperlinks für das Dokumentenarchiv des Informationsnetzes verwendet werden, ge- 5 kennzeichnet durch Mittel zur Veränderung der bei den an den Benutzer übermittelten Informationen vorhandenen Hyperlinks dahingehend, daß auf lokal beim Benutzer vorliegende Dokumente verwiesen wird.

25. Einrichtung nach einern der Ansprüche 14 bis 24, 10 gekennzeichnet durch ein Betriebssystem des Agenten. das Mittel zur parallelen Nachsuchung und Erfassung von Informationen in dem Informationsnetz bereitstellt.

26. Verfahren zum Nachsuchen und Erfassen von In- 15 formationen in einem Informationsnetz entsprechend einer Anforderung eines Benutzers, und zum Übermitteln dieser Informationen an den Benutzer über ein Leitungsnetz mit zeitlich variabler Übertragungsbandbreite, wobei das Informationsnetz mindestens einen 20 Informationen bereitstellenden Netzknoten aufweist und wobei die Informationen jeweils mindestens eine Referenz zu weiteren Informationen beinhalten. dadurch gekennzeichnet,

daß Informationen entsprechend einer Anforderung 25 des Benutzers angefordert werden.

daß bereits erhaltene Informationen auf Referenzen hin analysiert werden,

daß bei der Analyse gefundene Referenzen abgelegt

daß entsprechend referenzierte Informationen, entkoppelt vom Analyseprozeß, angeforden werden.

27. Verfahren nach Anspruch 26, dadurch gekennzeichnet, daß die bei der Analyse gefundenen Referenzen in eine URL-Liste abgelegt werden.

28. Verfahren nach Anspruch 26 oder 27, dadurch gekennzeichnet, daß die Übertragungsbandbreite des Leirungsnetzes überwacht wird und die referenzierten In-

formationen jeweils beim Vorliegen verfligbarer Bandbreiten angeforden werden. 29. Verfahren nach einem oder mehreren der Ausprü-

che 26 his 28, dadurch gekennzeichnet, daß die abgelegion Referenzen entsprechend einer Prioritätskette abgearbeitet werden.

30. Verfahren nach einem oder mehreren der Ansprü- 45 che 26 bis 29, dadurch gekennzeichnet, daß beim Vorliegen verfügbarer Bandbreiten jeweils ein neuer Programmfaden gebilder wird.

31. Einrichtung zum Durchsuchen eines Informationsnetzes nach von einem Benutzer angeforderten Infor- 50 mationen und zum Übermitteln der erfaßten Informationen an den Benutzer über ein Leitungsnetz mit zeitlich variabler Übertragungsbandbreite, wobei das Informationsnetz mindestens einen Informationen bereitstellenden Netzknoten aufweist, und wobei die Infor- 55 mationen jeweils mindestens eine Referenz zu weiteren Informationen beinhalten,

gekennzeichnet durch

Prozesmittel

zum Bearbeiten von Benutzeranforderungen und zur 60 entsprechenden Anforderung von Informationen aus dem Informationsnetz,

zur Analyse bereits erfaßter Informationen auf Referenzen hin, sowie

2ur Anforderung referenzierter Informationen in Ab- 65 hängigkeit von den Ergebnissen der Analyse; Speichermittel zum Speichern der Benutzeranforderungen, der bereits erfaßten Informationen, sowie der

18

bei der Analyse aufgefundenen Referenzen;

Zeitplanmittel zum Überwachen der Übertragungsbandbreite des Leitungsnetzes und zum Aktivieren der Prozeßmittel zur Anforderung referenzierter Informationen in Abhängigkeit von der jeweiligen Übertragungsbandbreite.

32. Einrichtung nach Anspruch 31, dadurch gekennzeichnet, daß die Prozestmittel zur Anforderung referenzierter Informationen, entsprechend der verfügbaren Übertragungsbandbreiten, neue Programmfäden für Anforderungen generieren.

33. Einrichtung nach Anspruch 31 oder 32, dadurch gekennzeichnet, daß als Speichermittel zum Speichern der bei der Analyse aufgefundenen Referenzen eine Liste von entsprechenden URLs vorgesehen ist.

34. Einrichtung nach einem oder mehreren der Anspriiche 31 bis 33, dadurch gekennzeichnet, daß als Speichermittel zum Speichern der bei der Analyse aufgefundenen Referenzen ein FIFO-Speicher vorgesehen

35. Einrichtung nach einem oder mehreren der Ansprüche 31 bis 34, dadurch gekennzeichnet, daß in den Speichermitteln Zusatzinformationen zur Erfassungstiefe der Nachsuchung abgelegt sind.


36. Einrichtung nach einem oder mehreren der Ansprüche 31 bis 35, dadurch gekennzeichnet, daß in den Speichermitteln sämtliche Benutzerauforderungen abgelegt sind.

37. Einrichtung nach einem oder mehreren der Ansprüche 31 bis 36, dadurch gekennzeichner, daß in den Speichermitteln von Seiten des Benutzers angegebene Filterbedingungen filr die Nachsuchung abgelegt sind. 38. Einrichung nach einem oder mehregen der Ansprüche 31 bis 37, dadurch gekennzeichnet, daß die Prozesmittel zur Anforderung referenzierter Informationen Mittel zur Priorisierung aufweisen, die bestimmte Informationen aufgrund von ichärenten Eigenschaften dieser Informationen im Vergleich mit anderen Informationen bei der Abwicklung der Anforderung priorisieren.

Hierzu 11 Seite(n) Zeichnungen


- Leerseite -


Nummer: Int. Cl.<sup>6</sup>; Offenlegungstag:



Nummer: Int. Cl.<sup>6</sup>: DE 197 25 264 A1 H 04 L 12/16 15. Oktober 1998


int. Cl.<sup>5</sup>: Offenlegungstag:








Nummer: Int. Cl.<sup>6</sup>; Offenlagungstag:








DE 197 25 264 A1 H 04 L 12/16 15. Oktober 1998





Nummer: int. Cl.<sup>6</sup>; Offenlegungstag: DE 197 25 264 A1 H 04 L 12/16 15. Oktober 1998

Solange	Solange kein Programmende	mendesignal empfangen	
S	Solange nicht abgesch	bgeschlossene Aufträge in Auftragsliste verfügbar	·
	7	Auftrag abschileßbar	. ·
		Solange nicht beschaffte Dokumente in Dokumentenliste verfügbar	gbar
	Auftrag aus aktiver Auftragsliste	Bandbreite, abzüglich Reserve, für neuen Tellauftrag	sive, für neuen Tellauftrag /
	entfernen	Maximale Anzahl Programmfäden für Agent noch	ifaden für Agent noch nicht erreicht N
·		Maximale Anzahi Programmfäden für Auftrag noch	ur Auftrag noch / nicht erreicht / N
-	Auftrag In Abhol- warteschlange	J (the seit oder Mengenbegrenzung noch nicht	2
	i e fa	Nächstes Dokument	
<del>.</del>	7	,	Auffragsabbruch
	Auftrag Informieren	Neuen Programmfaden slgnalis starten, der Dokument beschafft	signalisieren
	Nachster Auftrag		
×	Warte auf neuen Auffrag	Auftrag, Auftragsabbruch, Programmendesignal, Programmfadenendesignal oder frele Bandbreite	signal oder frele Bandbreite

ц\_

Nummer: Int. Cl.<sup>5</sup>; Offenlegungstag:

DE 197 26 264 A1 H 04 L 12/18 15. Oktober 1998

മ	Dokument anfordern
7	ent belnhaltet Referen
- 	Solange unbearbeitete Referenzen verfügbar
	Beschreibung des referenzierten Dokuments anfordern
	J Dokument genúgt Filterbedingungen
	Referenz auf lokale Quelle umschreiben
	Dokumentenreferenz in Dokumentenliste Referenz auf externe Quelle umschreiben des Auftrags einfügen
	Nächste unbearbeitete Referenz
Do	Dokument komprimieren
Do	Dokument dem Gesamtarchiv hinzufügen
Prog	Programmfadenende signalisieren

FIG. 78

Nummer: Int. Cl.<sup>6</sup>; Offenlagungstag:


DE 197 25 264 A1 H 04 L 12/16 15. Oktober 1998

Bei freier Bandbreite greift der Scheduler URL-Adressen von zu erfassenden Dokumenten aus dem URL-Pool ab und Initiiert deren Erfassung Scheduler Dokumentenerfassung Dokumentenerfassung HTML-Analyseprozeß HTML-Analyseproze8 **URL-Pool** Dokumentenerfassung Dokumentenerfassung HTML-AnalyseprozeB HTML-AnalyseprozeB Die Analyseprozesse fügen alle den Filterbedingungen genügenden Dokumentenadressen dem URL-Pool hinzu


Auftragsverwaltung

Die Auftragsverwaltung legt neu zu
erfassende Dokumentenadressen
im URL-Pool ab


FIG. 8




Nummer: Int. Cl.<sup>8</sup>: Offenlegungstag:



Nummer: Int. Cl.<sup>6</sup>: Offenlegungstag:



Nummer: Int. Cl.<sup>8</sup>: Offenlegungstag:



802 042/562